

階層型 RNN を用いたヒューマノイドロボットによる柔軟物折り畳み動作生成 Folding Flexible Object Task by a Humanoid Robot using Hierarchical Recurrent Neural Network

5115E009-9 鈴木 彼方 指導教員 尾形 哲也 教授
Kanata SUZUKI Prof. Tetsuya OGATA

概要：近年、ロボットは様々なタスク動作を行うことが可能となっており、多様な環境下における動作生成や人間とのインタラクションが期待されている。しかし実環境は多様に変化し、人間が動作モデルをデザインする事は限界がある。そこで本研究では複数の深層学習器を用いることで、オンラインに環境情報を取込みながら適応的に動作生成を行うモデルを提案する。取得する画像特徴量を人間による動作指示、及び、運動情報と共に時系列を考慮した統合学習を行うことで、従来手法より安定かつスムーズな動作生成を可能とする。また、動作教示に遠隔操作を用いることで学習データの有効性を保証し、直接教示の困難なロボットにも適用可能な汎用的なシステムを構築した。本研究の有効性を確認するため、複数の柔軟物に対し人間がインタラクティブに設置位置の変更や動作指示を行いながら動作生成を行った結果、ロボットは外部入力に合わせたタスク遂行が可能となった。

キーワード：階層型リカレントニューラルネットワーク、ヒューマノイドロボット、柔軟物体

Keywords: Hierarchical Recurrent Neural Network, Humanoid Robot, Flexible Object

1. 緒言

近年、ロボットは様々なタスク動作を行う事が可能となっており、多様な環境下における動作生成が期待されている。しかしながら従来の動作モデルをデザインする手法には限界があり、課題として以下の項目が考えられる。

(a)未知環境・物体に適応した動作生成(汎化能力)

(b)プリミティブな動作の獲得と利用

ロボットの活動する実環境下は逐次的に変化し、未知環境下において自発的に動作を変更する必要がある(a)。また、生成すべきタスク動作が複雑となった時、過去に獲得した動作シーケンスから必要な動作を組み合わせる事が求められる(b)。本研究では深層学習(Deep Learning)に基づき、取得するセンサ情報から直接的に動作を生成することで、これらの課題に取り組む。

従来研究では、深層強化学習により軌道を事前に設計することなく運動政策を獲得する手法が提案されている[1][2]。しかし動作の獲得までに多くの試行が必要であり、ロボットハードが変更された場合には適用が困難な場合がある。上記の課題に対し、我々は遠隔運動教示学習によるアプローチを試みたが、事前に設計した時間幅のみを考慮しているため、多分にノイズが含まれた環境下ではスムーズな動作生成が困難であった[3]。また、一部のセンサ情報から一意に決められた動作を生成しており、動作の分岐などを伴う複雑なタスク動作を考慮していなかった。これは記号接地論[4]に表されるような、状況依存性を含んでおり、従来研究でも言語と運動の統合的な学習が試みられている[5]。しかしながら、多くの研究はモデルの獲得する内部表現のみに注力しており、実タスクへの適用は行っていない。

本研究では現在状態から次状態を予測可能な神経回路モデルである MTRNN を用い、マルチモーダルなオンライン動作生成モデルを提案する。提案手法ではセンサ情報の意味関係を階層型に獲得することで、対象物体の状態や人間による外部指示にインタラクティブに対応した安定的な動作を実現させる。また、学習したシーケンスの中から、プリミティブな動作を組み合わせることによって、より複雑なタスク動作へ適用する。

2. 提案手法

本研究で用いる動作生成モデルを Fig.1 に示す。動作生成モデルは二種類の深層学習器から構成される。深層学習器とは複数階層からなる神経回路モデルを指し、実環境から得られる様々な高次元データを前処理なしに扱うことが可能である。また、様々な高次元データを同じフレームワークで扱うことが可能である。学習には二段階のフェーズがあり、はじめに人間が遠隔操作によりロボットに教示した運動データから、RGB 画像を Autoencoder により画像特徴量を抽出する。次に階層型の構造をした Recurrent Neural Network (RNN) を用いて、画像特徴量とロボットの運動情報(関節角度)と統合して学習を行う。また、本モデルは学習するセンサ情報が増えても、同じアーキテクチャで、より複雑なタスクに適用することが可能である。外

部からの動作指示を与えることにより、学習した動作の組み合わせや切り替えも表現することが可能である。

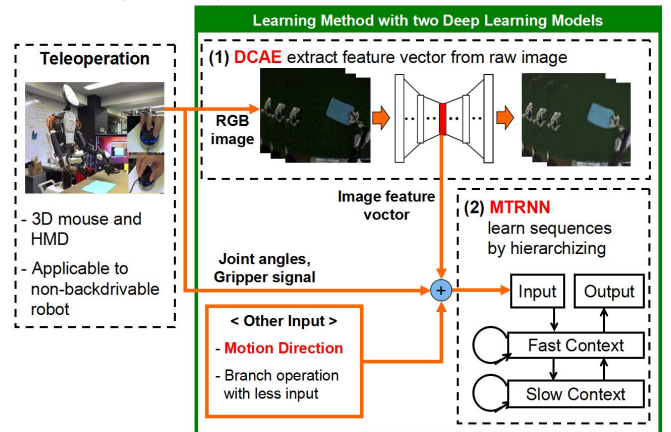


Fig.1 複数深層学習器による動作学習モデル

2.1 遠隔操作による運動教示

ロボットハードの違いから、教示データの作成手法は重要である。本研究では、人間が自分自身を操るようにロボットを遠隔操縦することで、直接動作を教示することが困難なロボットへも簡易に適用することが可能である。また、取得した教示データには動作学習に必要な情報が含まれることが保証される。

2.2 Deep Convolutional Autoencoder

Autoencoder とは砂時計型の深層学習器であり、入出力が高等写像となるように学習することで、中間層に低次元の特徴量が獲得されることが知られている。本研究で用いる Deep Convolutional Autoencoder (DCAE) では、入出力層近くに畳み込み層、及び、逆畳み込み層を導入し、通常畳み込み処理後に用いられる pooling 処理を行わないことで、入力データから情報を大きく損なうことなく、入出力の画像の解像度を保つ[6]。また、明暗などの実環境下における取得画像のノイズに対応するため、Levine らの研究[2]を参考にベナルティ項 g を導入することによって、取得する画像特徴量 f に時系列を考慮した拘束をかけた。

$$g(f_t) = ((f_{t+1} - f_t) - (f_t - f_{t-1}))^2$$

2.3 Multiple Timescales Recurrent Neural Network

本研究では運動情報とセンサ情報を統合的に学習するモデルとして、谷らによって提唱された Multiple Timescales Recurrent Neural Network (MTRNN)[7]を用いた。MTRNN は入出力層(IO層)と異なる発火速度 τ を持つ二種類のコンテキスト層(Cf層・Cs層)からなり、それぞれ再帰的な入力を持つ。時刻 t における i 番目のニューロンの内部状態 $u_i(t)$ は次式で与えられる。

$$u_i(t) = \left(1 - \frac{1}{\tau_i} \right) u_i(t-i) + \frac{1}{\tau_i} \left[\sum_{j \in N} w_{ij} x_j(t-1) \right]$$

時定数が大きいほど時間変化による各ノード値の変化は小さくなるため、時系列データのプリミティブを考慮し、階層化して学習することが可能である。

3. 実験設定

多自由度の工業用ヒューマノイドロボット Nextage を用い、先に挙げた課題(a)(b)における提案手法の有効性を評価するため、二種類の評価実験を行った。はじめに、形状の異なる複数のタオル折り畳みタスクを行い、モデルの汎化性能を評価する。次に、「上・右・左」からなる三種類の動作指示と共に対応するプリミティブな動作からなる衣服折り畳みタスクを行い、モデルの適用性、及び、インタラクティブな動作プリミティブの組み合わせや切り替えが可能であるかを確認する。

教示データセットとして卓上六箇所に設置された柔軟物体の折り畳み動作を 5[step/sec]で 152[step]取得し、学習させる。センサ情報として 112x112x3[pixel]の合計 37632 次元のカメラ画像から DCAE により画像特徴量 10 次元を抽出する。MTRNN の入力データとして、実験 1 では取得した関節角度 12 次元と Gripper 開閉を加えた合計 24 次元、実験 2 では動作指示を加えた合計 27 次元を扱う (Table.1)。

ノードタイプ	ノード名	ノード数	時定数 τ
Input-Output (IO)	関節角度	12	-
	Gripper 開閉	2	-
	画像特徴量	10	-
	動作指示*	3	-
Fast Context (Cf)	Fast Context	80	5
Slow Context (Cs)	Slow Context	20	50

Table.1 MTRNN の各ノード設定(*実験 2 のみ使用)

4. 結果と考察

4.1 実験 1: タオル折り畳みタスク

物体位置・種類・形状に対するタスク動作生成の汎化能力(a)を確認するため、未学習位置に設置したタオルを二つ折りにする動作を繰り返し生成した。オンラインに画像情報を取り込むことで、タオルの設置状態に合わせて適切なタオル位置で動作を生成可能であることが確認された (Fig.2)。加えて、似た形状のタオルをいくつか学習することで同様にタスクの遂行が可能であり、タスク終了後の折り畳み面積率 (A.C.Rate) が 67.5% は 97.8% の割合であった (Fig.3)。また、本モデルで獲得されたコンテキスト層を主成分分析によって可視化した結果、動作アトラクタを獲得しており、繰り返し動作を行った際にも内部状態が初期状態に戻ることで、従来手法 [3] と比較して安定的な動作生成が可能となった (Fig.4)。

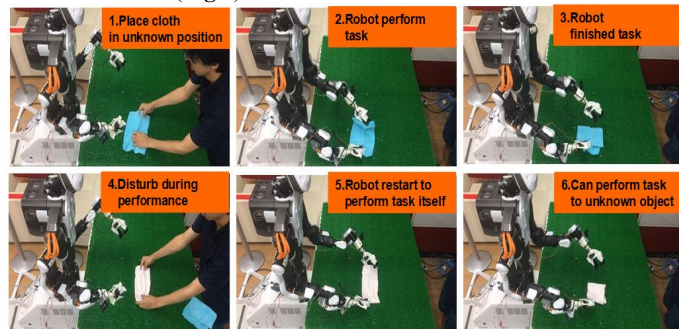


Fig.2 タオル折り畳み動作




Fig.3 タスク成功率




Fig.4 内部状態

4.2 実験 2: 衣服折り畳みタスク

プリミティブな動作を利用したインタラクティブな動作切り替え (b) を確認するため、衣服の折り畳み動作生成を行った。ロボットは衣服を 4 回折り畳むうちに三種類の動作指示がそれぞれ与えられる。4 回目の動作移行時には 1 回目と同パターンが入力が与えられるため、画像情報と時系列のコンテキストを考慮したうえで適切な動作を生成する必要がある。

実験の結果、ロボットは動作指示に基づいて、インタラクティブに動作を分岐を行い、未学習位置でのタオルの折り畳みタスクを生成することが可能となった (Fig.5)。また、MTRNN は動作指示と画像情報の内部表現を階層的型 Context 層に自己組織的に獲得しており、限られたセンサ情報から状況依存性を考慮した意味関係が表現されていることが確認された (Fig.6)。




Fig.5 衣服折り畳み動作

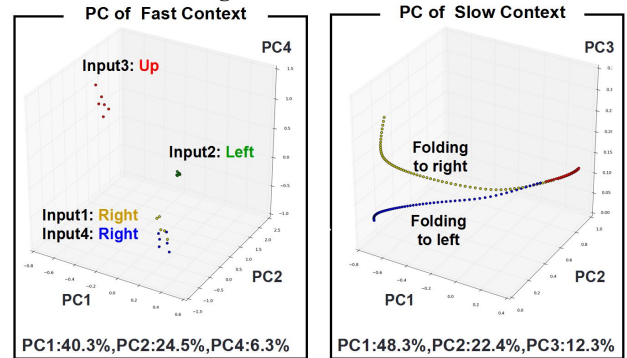


Fig.6 動作指示に基づく分岐

5. 結言

本研究では実環境下におけるロボットの動作生成において、階層型 RNN を用いた時系列統合学習を行うことで、オンラインでの安定的な動作生成を実現し、未知物体/位置への高い汎化能力を確認した。また、同一のアーキテクチャを用いて、複数の動作指示を加えて学習することで、動作プリミティブの切り替え・組み合わせによる複雑なタスクを実現した。今後は異なるロボットへの適用を行う。

参考文献

- [1] S.Levine, et. al., "Learning Hand-Eye Coordination for Robotic Grasping with Deep Learning and Large-Scale Data Collection," arXiv preprint arXiv:1603.02199, 2016.
- [2] S.Levine, et. al., "End-to-End Training of Deep Visuomotor Policies," arXiv preprint arXiv:1504.00702, 2015.
- [3] P.C.Yang, et. al., "Repeatable Folding Task by Humanoid Robot Worker using Deep Learning," IEEE Robotics and Automation Letters (RA-L), issue 99, 2016.
- [4] S.Harned, "The symbol grounding problem", Physica D, Vol.42, pp.335--346, 1990.
- [5] T.Yamada, et. al., "Dynamical Integration of Language and Behavior in a Recurrent Neural Network for Human-Robot Interaction," Frontiers in Neurorobotics, Vol.10, Article 5, pp.1-17, 2016.
- [6] J.Masci, et. al., "Stacked Convolutional Auto-Encoder for Hierarchical Feature Extraction", IEEE Computer Society Conference on Computer Vision and Recognition (CVPR), 2015.
- [7] Y.Yamashita, et. al., "Emergence of functional hierarchy in a multiple timescale neural network model: a humanoid robot experiment", PLoS Computational Biology, 4, 11, pp.e000220-1--e1000220-18, 2008.